

AUTOMATIC STRESS DETECTION USING NON-EEG BIOLOGICAL SIGNAL

Ondřej Malina

Bachelor Degree Programme (3.), FEEC BUT

E-mail: xmalin27@stud.feec.vutbr.cz

Supervised by: Ing. Radovan Smíšek

E-mail: xsmise00@stud.feec.vutbr.cz

Abstract: This work deals with the issue of stress detection using non-EEG biosignals. The main goal of this work is to create a functional program in MATLAB programming language that would allow detection and classification of stress, from easily readable data acquired on commercially available devices. So that results obtained by this algorithm can be used for predicting and preventing stress during daily routine activities.

Keywords: stress classification, non-EEG biosignals, MATLAB, c-means, PhysioNet

1 ÚVOD

V dnešní době můžeme poměrně přesně detekovat stres pomocí analýzy EEG signálů. Tato metoda má ovšem velké omezení v tom, že snímání EEG záznamů lze realizovat pouze za pomoci specializovaného, cenově poměrně nákladného vybavení a nelze ji efektivně využít pro dlouhodobější detekci v běžných podmínkách. Oproti tomu detekce stresu pomocí non-EEG signálů je možné lehce realizovat i v běžných životních situacích, což této metodě poskytuje široké pole uplatnění například při nastavování dobré strategie zvládání stresu v zaměstnání, či během řízení auta, predikování suicidálního chování u psychiatrických pacientů nebo ověřování účinnosti medikace psychofarmak. Tuto skutečnost ještě podporuje fakt, že v poslední době dochází k masivnímu rozšiřování zařízení typu fitness smartwatch a healthwatch, které jsou cenově dostupné a jsou schopny detekovat řadu biosignálů využitelných k detekci stresu. Tato práce si klade za cíl navrhnout vhodný algoritmus, který by za využití fuzzy metody c-means dokázal rozeznat u snímaného člověka stresovou reakci a tuto stresovou zátěž pak vhodně klasifikoval dle druhu stresu na stres fyzický či psychický (a psychický stres, popřípadě dále klasifikovat na stres kognitivní či emoční). K detekci a klasifikaci stresu tento algoritmus využívá data získaná z pěti různých non-EEG signálů pořízených pomocí komerčně vyráběného náramkového senzoru a prstového pulzního oxymetru.

2 DATA

Algoritmus byl navržen a je zdokonalován za pomoci databáze signálů, která byla naměřena v Laboratoři kvality života na univerzitě v Texasu v Dallasu (Quality of Life Laboratory at University of Texas at Dallas). Tato data jsou volně přístupná v databázi fyziologických signálů Physionet [1]. Tato konkrétní databáze obsahuje signály pořízené od 20 subjektů (14 mužů a 6 žen, ve věku mezi 19 a 33 lety). U každého subjektu byla snímána tepová frekvence, saturace krve, pohyby zápěstí, změna kožní konduktance (EDA) a teplota pokožky. Subjekty byly během snímání vystaveny stresorům navozující fyzický, psychický kognitivní a psychický emoční stres. Jako stresory byl použit běh na běžecím trenažéru, řešení početních příkladů, test barevného čtení (Stroopův test) a sledování ukázky z hororového filmu. Mezi fázemi, kdy byli subjekty exponovány stresory, jsou vloženy fáze, kdy se subjekty nacházeli v relaxovaném stavu. Ke každému záznamu je přiložena anotace, která byla použita k ověření úspěšnosti detekce algoritmu. Tato anotace obsahuje údaje o tom, v kterých časech byli subjekty vystaveny působení stresorů, kdy bylo toto působení stresorů ukončeno a subjekt byl převeden do stavu relaxace. Časový úsek od začátku působení stresoru až po jeho ukončení je brán jako období, ve kterém by se u subjektu měla projevit stresová reakce. V čase mezi působením stresorů je předpokládáno, že se subjekt nacházel v relaxovaném stavu.



Obrázek 1: Snímací zařízení použita během experimentu. Zařízení Affectiva Q (a), oxymetr Nonin 3150 (b) [1]

Tepová frekvence a saturace krve byly snímány pomocí pulzního oxymetru Nonin 3150 Wireless WristOx2 (viz obrázek 1) se vzorkovací frekvencí $f_{vz} = 1$ Hz. Signály z akcelerometru, EDA a teplota pokožky byly naměřeny pomocí zařízení Affectiva Q (viz obrázek 1) se vzorkovací frekvencí $f_{vz} = 8$ Hz. Signály v této databázi jsou již předzpracovány a byly z nich odstraněny neplatné datové body (bližší údaje o tom, jaké metody byly použity k předzpracování a úpravě signálu nejsou v článku [2] obsaženy). [2]

3 KLASIFIKAČNÍ ALGORITMUS

Celý klasifikační algoritmus je realizovaný v prostředí MATLAB. Pro nahrání dat z databáze PhysioNet je nejprve nutné do programu přidat volně šiřitelnou knihovnu WDFB (WaveForm DataBase), která obsahuje nástroje pro zpracování, automatickou analýzu a vytváření nových záznamů signálů. Mimo jiné tato knihovna obsahuje funkci plotATM, kterou je vhodné použít pro vizualizaci průběhu a rozsahu signálů. Navržený algoritmus pro detekci a klasifikaci stresu je znázorněn na obrázku 2. Po získání dat z databáze dochází k standardizaci dat získaných z akcelerometru dle vzorce (1), kde z = Z-skóre, μ = střední hodnota, σ = směrodatná odchylka, i - je index příznaku. [3]

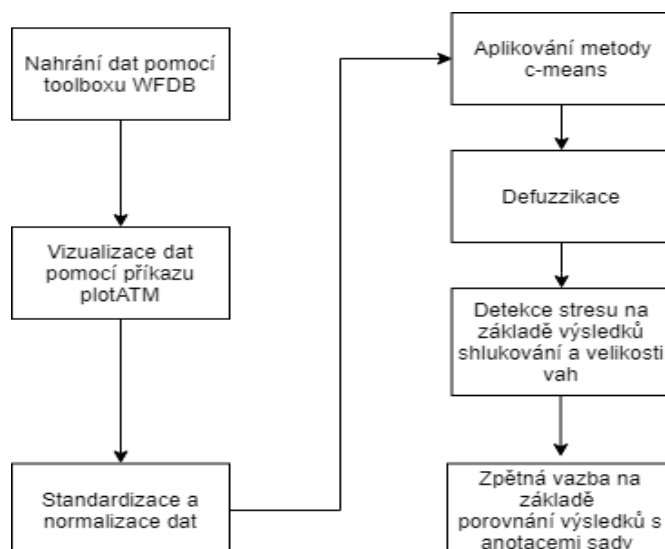
$$z_i = \frac{x_i - \mu_i}{\sigma_i}, \quad (1)$$

U ostatních dat je provedena normalizace dat dle vzorce (2), kde j - je index objektu, i - je index příznaku. [3]

$$z_{ij} = \frac{x_i - \min_j(x_{ij})}{\sigma_{\max_j(x_{ij}) - \min_j(x_{ij})}} \quad (2)$$

Tím dochází k homogenizaci dat. Takto upravená data jsou dále podrobena fuzzy shlukování na základě shlukovací metody c-means. Shlukování je prováděno pro každý non-EEG signál zvlášť, bez závislosti na ostatních signálech. Ve výsledku to tedy znamená, že až na údaje z akcelerometru (tři signály z jednotlivých os akcelerometru) se jedná o jednorozměrné signály. Umístění výchozích centroidů je zvoleno napevno na základě empirických zkušeností, získaných odzkoušením několika různých variant postavení výchozích centroidů, z nichž použitá varianta byla vybrána na základě dobrého rozdělení prvků a nízkého počtu iterací potřebných pro dosažení finálních shluků. Hodnotu parametru q , který má řídit neostrost hranic výsledných shluků, je nastavena na hodnotu 2, velikost minimálního rozdílu mezi dvěma iteracemi ϵ pak na hodnotu 10^{-5} . [3] Byli odzkoušeny i jiné varianty hodnoty ϵ , ale všechny menší hodnoty než 10^{-5} aproximovaly vždy ke stejnému výsledku. Počet výchozích centroidů je stanoven na tři tak, aby od sebe rozdělené shluky reprezentovali příslušnost dat k stavu fyzického stresu, psychického stresu či relaxace. Takto získaná data jsou posléze defuzzifikována. V dalším kroku jsou k jednotlivým non-EEG signálům přidělené váhy, podle toho, jak dobře došlo k oddělení shluků. Příslušnost dat k určitému shluku je násobena příslušnou váhovou hodnotou. Takto vynásobené příslušnosti různých signálů, reprezentující stejný stav (např. fyzický stres) ve stejném časovém okamžiku, jsou sumarizovány. Přesáhne-li tato suma určitou předem stanovenou prahovou hodnotu je v tento časový okamžik detekován stav odpovídající příslušnému shluku. Rozdílná vzorkovací frekvence signálů je řešena interpolací vzorků signálu

tepové frekvence a saturace krve. Psychický stres lze dále dělit na stres emoční a kognitivní. K tomuto dělení dochází na základě toho, ve kterých non-EEG signálech byl psychický stres detekován či nikoliv. Získané výsledky je možné porovnat s anotacemi přiloženými v databázi k signálům. Na jejich základě je možné upravovat váhy jednotlivých signálů i prahové hodnoty, či jinak optimalizovat algoritmus.



Obrázek 2: Blokové schéma použitého algoritmu

Vzhledem k nejlepšímu oddělení shluků byla největší váha přidělena datům získaných pomocí akcelerometru, po ní následovali údaje o tepové frekvenci, tyto non-EEG signály zároveň úzce souvisí se zvýšenou fyzickou aktivitou, a proto byli použity při její detekci. U údajů z EDA a teploty pokožky, nedošlo k dobrému rozdělení shluků, a proto k nim byla přiřazena malá váha. Tyto údaje slouží především k detekci psychického stresu.

4 DOSAVADNÍ VÝSLEDKY

Klasifikační úspěšnost navrženého algoritmu je zobrazena v tabulce 1. V této fázi vývoje je nutné bohužel konstatovat, že dosavadní výsledky algoritmu nejsou doposud na takové úrovni, aby bylo možné algoritmus využít v praxi a bude nutná jeho optimalizace. Malou úspěšnost navrženého algoritmu připisují na vrub především špatnému nastavení vah a prahů, jejichž hodnoty byli doposud upravovány pouze manuálně. Je ovšem možné očekávat, že se zařazením bloku, ve kterém se budou za pomoci strojového učení automaticky upravovat váhy a prahové hodnoty dosáhneme citelně lepších výsledků. [4]

Tabulka 1: Tabulka dosavadních výsledků

	SPECIFICITA	SENZITIVITA	PŘESNOST
CELKOVÝ STRES	52,5 %	68,3 %	60 %
FYZICKÝ STRES	65,3 %	51,8 %	58 %
PSYCHICKÝ STRES	70,6 %	47,3 %	63,1 %
EMOČNÍ STRES	81,1 %	26,5 %	72 %
KOGNITIVNÍ STRES	83 %	54,9 %	78 %

Momentální nedostatečnost klasifikačního navrženého algoritmu je patrná i když srovnáme dosažené výsledky s výsledky jiných autorů, zabývajících se stejnou problematikou. V tabulce 2. je srovnání senzitivity a specifity navrženého algoritmu s metodou GMM publikovanou v článku [2], která byla aplikována na stejných datech. Dále je v tabulce 3. je porovnávána přesnost algoritmu při detekci celkového stresu s výsledky metod strojového učení, tak jak jsou publikovány v článku [4]

Tabulka 2: Srovnání senzitivity a specifity navrhnutého algoritmu a metody GMM

		FYZICKÝ STRES	EMOCIONÁLNÍ STRES	KOGNITIVNÍ STRES
SENZITIVITA	GMM metoda	85,4 %	77,2 %	86,4 %
	Navrhnutý algoritmus	51,8 %	26,5 %	54,9 %
SPECIFICITA	GMM metoda	93,3 %	70,2 %	86,4 %
	Navrhnutý algoritmus	65,3 %	81,1 %	83 %

Tabulka 3: Srovnání přesnosti navrhnutého algoritmu s metodami strojového učení

METODA	PŘESNOST
K-NN	64,28 %
SVM (lineární jádro)	68,66 %
SVM (Gaussovské jádro)	67,48 %
Naïve Bayes	67,57 %
Random forest	72,15 %
logická regrese	77,27 %
Navrhnutý algoritmus	60 %

Klasifikace psychického stresu na kognitivní a emoční stres není zcela běžné a nepodařilo se mi dohledat žádné literární prameny, které by popisovali příznaky těchto stavů projevující se v použitých non-EEG signálech. O jejich rozlišení jsme se pokusil především proto, že autoři článku [2], kteří svoji metodu aplikovali na stejných datech, dosáhli dobrých výsledků při rozlišování těchto dvou stresových situací. Při rozlišení těchto dvou druhů stresu, jsem vycházel především z předpokladu, že kognitivní psychický stres se neprojeví na údajích z akcelerometru. Tato úvaha se ovšem ukázala jako mylná. Vzhledem k výsledkům jiných autorů je ovšem možné předpokládat, že zařazením bloku aplikující některou z metod strojového učení, bude možné tyto dva stavy od sebe odlišit. [2] [4]

5 ZÁVĚR

Přestože dosavadní výsledky nejsou zatím příliš uspokojivé a rozhodovací algoritmus potřebuje ještě řadu optimalizací nasvědčují dosavadní výsledky tomu, že detekce stresu z non-EEG signálů za pomoci fuzzy shlukovací metody c-means má určitý potenciál a snad ji bude možné v budoucnu prakticky aplikovat při predikci a eliminaci stresových situací v každodenním životě.

REFERENCE

- [1] Goldberger AL, Amaral LAN, Sklo L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng CK, Stanley HE. *PhysioBank, Physio-Toolkit a PhysioNet: součásti nového výzkumného zdroje pro komplexní fyziologické signály*. *Cirkulace* 101 (23): e215-e220 [Circulation Electronic Pages; <http://circ.ahajournals.org/content/101/23/e215>];
- [2] BIRJANDTALAB, Javad, Diana COGAN, Maziyar Baran POUYAN a Mehrdad NOURANI. *A Non-EEG Biosignals Dataset for Assessment and Visualization of Neurological Status*. In: 2016 IEEE International Workshop on Signal Processing Systems (SiPS) [online]. IEEE, 2016, 2016, s. 110-114 [cit.2018-11-26]. DOI: 10.1109/SiPS.2016.27. ISBN 978-1-5090-3361-4. Dostupné z: <http://ieeexplore.ieee.org/document/7780081/>
- [3] RONHZINA, Marina. Umělá inteligence v medicíně AUIIN (6-8): text přednášky.
- [4] JIMENEZ-LIMAS, Marco A., Carlos A. RAMIREZ-FUENTES, Blanca TOVAR-CORONA a Laura I. GARAY-JIMENEZ. *Feature selection for stress level classification into a physiological signals set*. In: 2018 15th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE) [online]. IEEE, 2018, 2018, s. 1-5 [cit. 2019-01-02]. DOI: 10.1109/ICEEE.2018.8533968. ISBN 978-1-5386-7033-0. Dostupné z: <https://ieeexplore.ieee.org/document/8533968/>